



(21) 申请号 202410585343.2

(22) 申请日 2024.05.11

(71) 申请人 清华大学

地址 100084 北京市海淀区清华园

(72) 发明人 封硕 白若瑄 张毅 杨敬轩

陆秋婧

(74) 专利代理机构 北京安信方达知识产权代理

有限公司 11262

专利代理师 龙洪 栗若木

(51) Int. Cl.

G06F 18/2415 (2023.01)

G06F 18/214 (2023.01)

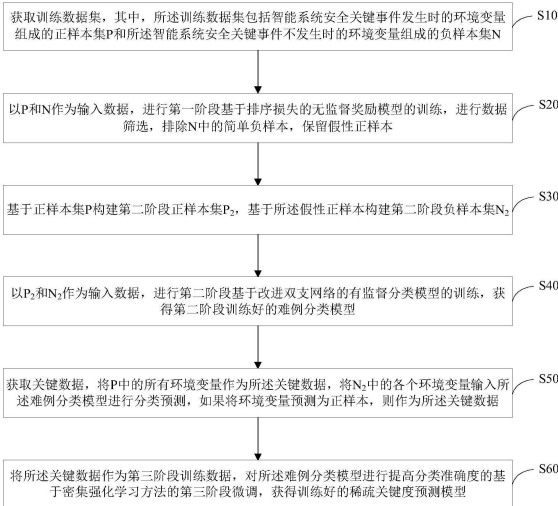
权利要求书3页 说明书8页 附图3页

(54) 发明名称

一种稀疏关键度预测模型训练方法、预测系统和方法

(57) 摘要

一种稀疏关键度预测模型训练方法、预测系统和方法,所述训练方法包括:获取智能系统安全关键事件发生时的正样本集P和不发生时的负样本集N,根据P和N进行第一阶段无监督奖励模型训练,排除N中简单负样本,保留假性正样本;基于正样本集P和假性正样本构建正样本集 P_2 和负样本集 N_2 ,进行第二阶段基于改进双支网络的有监督分类模型的训练,获得难例分类模型;获取关键数据作为第三阶段训练数据,对难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得稀疏关键度预测模型,能有效解决安全关键事件环境变量的稀疏度灾难,解决了极度不平衡数据集的学习问题,获得了高精度的智能系统安全关键事件概率预测模型。



1. 一种稀疏关键度预测模型训练方法,其特征在于,包括:

获取训练数据集,其中,所述训练数据集包括智能系统安全关键事件发生时的环境变量 X_i 组成的正样本集P和所述智能系统安全关键事件不发生时的环境变量 X_i 组成的负样本集N;

以P和N作为输入数据,进行第一阶段基于排序损失的无监督奖励模型的训练,进行数据筛选,排除N中的简单负样本,保留假性正样本;

基于正样本集P构建第二阶段正样本集 P_2 ,基于所述假性正样本构建第二阶段负样本集 N_2 ,其中, $P_2 = \{(X_i, Y_i) | Y_i = 1\}$, $N_2 = \{(X_i, Y_i) | Y_i = 0\}$;

以 P_2 和 N_2 作为输入数据,进行第二阶段基于改进双支网络的有监督分类模型的训练,获得第二阶段训练好的难例分类模型;

获取关键数据,包括:将P中的所有 X_i 作为所述关键数据,将 N_2 中的各个 X_i 输入所述难例分类模型进行分类预测,如果将 X_i 预测为正样本,则将 X_i 作为所述关键数据;

将所述关键数据作为第三阶段训练数据,对所述难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得训练好的稀疏关键度预测模型。

2. 如权利要求1所述的稀疏关键度预测模型训练方法,其特征在于:

所述智能系统为智能无人系统,所述智能无人系统包括机器人、自动驾驶汽车、无人机、智能医疗系统、智能农业系统、智能家居系统、智能物流系统、智能火箭系统、人脸识别系统中的任意一种或多种;

其中,所述机器人的安全关键事件包括跌倒、碰撞、电气危险、人生伤害中的任意一种或多种;

所述自动驾驶汽车的安全关键事件包括碰撞、误解交通环境、黑客远程攻击中的任意一种或多种。

3. 如权利要求1所述的稀疏关键度预测模型训练方法,其特征在于,所述以P和N作为输入数据,进行第一阶段基于排序损失的无监督奖励模型的训练,并进行数据筛选,排除N中的简单负样本,保留假性正样本,包括:

循环执行以下步骤,对所述无监督奖励模型进行第一迭代训练,直到所述训练数据集的稀疏度小于或等于稀疏度阈值,获取所有所述假性正样本:

对于P中的每个正样本 X_i ,根据预定策略在N中选择对应的负样本 X_j 构建正负样本对 (x_p, x_n) ,其中, x_p 为P中的 X_i , x_n 为N中的 X_j ;

依次对每一个所述正负样本对 (x_p, x_n) 分别执行以下操作:将所述正负样本对 (x_p, x_n) 作为无监督奖励模型的输入数据,并获取相应的输出标量;根据所述输出标量和奖励函数计算奖励值,比较所述奖励值和奖励阈值,当所述奖励值小于所述奖励阈值时,将所述正负样本对 (x_p, x_n) 中的 x_n 作为所述简单负样本进行排除,否则将 x_n 作为所述假性正样本保留在N中;

计算所述训练数据集的稀疏度,判断所述稀疏度与所述稀疏度阈值的关系,当所述稀疏度大于所述稀疏度阈值时,进行下一次所述第一迭代训练。

4. 如权利要求3所述的稀疏关键度预测模型训练方法,其特征在于,所述计算所述训练数据集的稀疏度,包括:

根据公式 $IR = |N| / |P|$ 计算所述稀疏度,其中IR代表所述稀疏度, $|N|$ 为负样本集N中所

述假性正样本 X_i 的数量, $|P|$ 为正样本集 P 中正样本 X_i 的数量。

5. 如权利要求1所述的稀疏关键度预测模型训练方法, 其特征在于, 所述以 P_2 和 N_2 作为输入数据, 进行第二阶段基于改进双支网络的有监督分类模型的训练, 获得第二阶段训练好的难例分类模型, 包括:

将 P_2 和 N_2 输入所述有监督分类模型, 其中, 所述有监督分类模型包括所述双支网络和第二优化器;

循环执行以下步骤, 对所述有监督分类模型进行第二迭代训练, 直到分类损失小于或者等于第二预设损失阈值, 获取并保存第二阶段训练好的难例分类模型:

基于所述双支网络, 分别得到 P_2 对应的第一特征 p_a 和 N_2 对应的第二特征 p_b , 并根据所述第一特征 p_a 和所述第二特征 p_b , 得到正负类别概率向量 p ;

根据分类损失函数计算所述分类损失, 其中所述分类损失函数的参数包括所述正负类别概率向量 p ;

判断所述分类损失与所述第二预设损失阈值的关系, 当所述分类损失大于所述第二预设损失阈值时, 采用第二优化器更新所述有监督分类模型的参数, 包括更新所述双支网络的参数。

6. 如权利要求5所述的稀疏关键度预测模型训练方法, 其特征在于, 所述基于所述双支网络, 分别得到 P_2 对应的第一特征 p_a 和 N_2 对应的第二特征 p_b , 并根据所述第一特征 p_a 和所述第二特征 p_b , 得到正负类别概率向量 p , 包括:

根据所述双支网络中的上支, 对 P_2 和 N_2 进行类平衡采样, 得到上输入样本 (x_a, y_a) , 并基于各个所述上输入样本 (x_a, y_a) 进行第一骨干网络特征提取, 得到第一特征 p_a , 其中, 所述第一骨干网络特征提取关注正样本特征学习;

根据所述双支网络中的下支, 对 P_2 和 N_2 进行均匀采样, 得到下输入样本 (x_b, y_b) , 并基于各个所述下输入样本 (x_b, y_b) 进行第二骨干网络特征提取, 得到第二特征 p_b , 其中, 所述第二骨干网络特征提取关注负样本特征学习;

采用正则化后的线性分类头, 将所述第一特征 p_a 和所述第二特征 p_b 进行进行拼接, 得到正则化特征;

采用softmax层对所述正则化特征进行概率分布计算, 得到所述正负类别概率向量 p ;

其中, 所述有监督分类模型还包括所述线性分类头和所述softmax层。

7. 如权利要求6所述的稀疏关键度预测模型训练方法, 其特征在于, 所述根据分类损失函数计算所述分类损失, 包括:

根据所述分类损失函数 $L=L_a(p, y_a)+L_b(p, y_b)$ 计算所述分类损失, 其中, L_a 为焦点损失函数, L_b 为交叉熵损失函数。

8. 如权利要求6所述的稀疏关键度预测模型训练方法, 其特征在于, 所述将所述关键数据作为第三阶段训练数据, 对所述难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调, 获得训练好的稀疏关键度预测模型, 包括:

将所述难例分类模型转换为初始离线深度 Q 网络, 所述初始离线深度 Q 网络为第三迭代训练中第一次迭代训练对应的当前离线深度 Q 网络;

循环执行以下步骤, 对所述当前离线深度 Q 网络进行所述第三迭代训练, 直到第三损失小于或者等于第三预设损失阈值, 获取并保存训练好的稀疏关键度预测模型:

将所述关键数据作为输入数据,对所述当前离线深度Q网络进行训练,并计算所述当前离线深度Q网络对应的Q值,其中,所述Q值为预测结果为正样本的概率;

根据Q损失函数计算所述第三损失,其中,所述Q损失函数的参数包括所述Q值;

判断所述第三损失与所述第三预设损失阈值的关系,当所述第三损失大于所述第三预设损失阈值时,采用第三优化器更新所述线性分类头和所述softmax层的参数,并相应的更新所述当前离线深度Q网络。

9.一种稀疏关键度预测系统,其特征在于,包括:测试数据获取模块和基于权利要求1-8任一项所述的稀疏关键度预测模型训练方法获得的稀疏关键度预测模型;

所述测试数据获取模块用于获取智能系统安全关键事件的实际环境X;

所述稀疏关键度预测模型用于预测所述实际环境X下安全关键事件的发生概率,其中,所述发生概率为预测X为正样本的概率。

10.一种稀疏关键度预测方法,其特征在于,所述方法由权利要求9所述的稀疏关键度预测系统执行,包括:

基于测试数据获取模块获取智能系统安全关键事件的实际环境X;

将X输入稀疏关键度预测模型,对所述实际环境X下安全关键事件的发生概率进行预测,其中,所述发生概率为预测X为正样本的概率。

一种稀疏关键度预测模型训练方法、预测系统和方法

技术领域

[0001] 本文涉及智能系统稀疏安全风险评估领域,尤指一种稀疏关键度预测模型训练方法、预测系统和方法。

背景技术

[0002] 目前,智能系统在日常的生产和生活中应用逐渐广泛,在各种智能系统极大的改变了生产和生活方式的同时,也带来了各种各样的事故,引发了人们对智能系统安全性的关注,准确预测智能系统发生安全关键事件的概率对于识别智能系统的安全风险意义重大,能够保障生命财产安全,还能进一步促进智能系统的规模化应用和商业化落地。现在关于发生安全关键事件的概率预测方法主要有两种,一种是基于指标的方法,由于智能系统的动力学复杂性,难以设计适合于智能系统的指标,而且现有的基于指标的方法预测精度较低;另一种是基于模型的方法,但其难以解决样本的稀疏度灾难问题,造成该方法在极端不平衡数据集上的高精度模型训练面临很多困难,使得基于模型的方法难以落地应用。

发明内容

[0003] 本申请提供了一种稀疏关键度预测模型训练方法、预测系统和方法,能有效解决智能系统安全关键事件的环境变量稀疏度灾难,解决了极度不平衡数据集难以学习的问题,获得了高精度的智能系统安全关键事件概率预测模型。

[0004] 一方面,本申请实施例提供了一种稀疏关键度预测模型训练方法,包括:

[0005] 获取训练数据集,其中,所述训练数据集包括智能系统安全关键事件发生时的环境变量 X_i 组成的正样本集P和所述智能系统安全关键事件不发生时的环境变量 X_i 组成的负样本集N;

[0006] 以P和N作为输入数据,进行第一阶段基于排序损失的无监督奖励模型的训练,进行数据筛选,排除N中的简单负样本,保留假性正样本;

[0007] 基于正样本集P构建第二阶段正样本集 P_2 ,基于所述假性正样本构建第二阶段负样本集 N_2 ,其中, $P_2 = \{(X_i, Y_i) | Y_i = 1\}$, $N_2 = \{(X_i, Y_i) | Y_i = 0\}$;

[0008] 以 P_2 和 N_2 作为输入数据,进行第二阶段基于改进双支网络的有监督分类模型的训练,获得第二阶段训练好的难例分类模型;

[0009] 获取关键数据,包括:将P中的所有 X_i 作为所述关键数据,将 N_2 中的各个 X_i 输入所述难例分类模型进行分类预测,如果将 X_i 预测为正样本,则将 X_i 作为所述关键数据;

[0010] 将所述关键数据作为第三阶段训练数据,对所述难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得训练好的稀疏关键度预测模型。

[0011] 另一方面,本申请实施例还提供了一种稀疏关键度预测系统,包括:测试数据获取模块和基于上述实施例所述的稀疏关键度预测模型训练方法获得的稀疏关键度预测模型;

[0012] 所述测试数据获取模块用于获取智能系统安全关键事件的实际环境X;

[0013] 所述稀疏关键度预测模型用于预测所述实际环境X下安全关键事件的发生概率,

其中,所述发生概率为预测X为正样本的概率。

[0014] 另一方面,本申请实施例还提供了一种稀疏关键度预测方法,所述预测方法由上述实施例所述的稀疏关键度预测系统执行,包括:

[0015] 基于测试数据获取模块获取智能系统安全关键事件的实际环境X;

[0016] 将X输入稀疏关键度预测模型,对所述实际环境X下安全关键事件的发生概率进行预测,其中,所述发生概率为预测X为正样本的概率。

[0017] 与相关技术相比,本申请实施例的一种稀疏关键度预测模型训练方法、预测系统和方法,所述稀疏关键度预测模型训练方法基于三阶段训练框架,通过第一阶段的基于排序损失的无监督奖励模型的训练,剔除了简单负样本,极大降低了训练数据集的不平衡性,第二阶段基于改进双支网络的有监督分类模型的训练关注难例的精细分类,获得难例分类模型,再通过对难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得稀疏关键度预测模型,训练过程能够有效解决智能系统安全关键事件的环境变量的稀疏度灾难,解决了极度不平衡数据集难以学习的问题,获得了高精度的智能系统安全关键事件概率预测模型。

[0018] 本申请的其它特征和优点将在随后的说明书中阐述,并且,部分地从说明书中变得显而易见,或者通过实施本申请而了解。本申请的其他优点可通过在说明书以及附图中所描述的方案来实现和获得。

附图说明

[0019] 附图用来提供对本申请技术方案的理解,并且构成说明书的一部分,与本申请的实施例一起用于解释本申请的技术方案,并不构成对本申请技术方案的限制。

[0020] 图1是本申请实施例的稀疏关键度预测模型训练方法流程图;

[0021] 图2是本申请实施例的稀疏关键度预测系统示意图;

[0022] 图3是本申请实施例的稀疏关键度预测方法流程图;

[0023] 图4是本申请具体示例的第一阶段基于排序损失的无监督奖励模型的训练效果示意图;

[0024] 图5是本申请具体示例的ROC曲线示意图;

[0025] 图6是本申请具体示例的PR曲线示意图。

具体实施方式

[0026] 本申请描述了多个实施例,但是该描述是示例性的,而不是限制性的,并且对于本领域的普通技术人员来说显而易见的是,在本申请所描述的实施例包含的范围内可以有更多的实施例和实现方案。尽管在附图中示出了许多可能的特征组合,并在具体实施方式中进行了讨论,但是所公开的特征的许多其它组合方式也是可能的。除非特意加以限制的情况以外,任何实施例的任何特征或元件可以与任何其它实施例中的任何其他特征或元件结合使用,或可以替代任何其它实施例中的任何其他特征或元件。

[0027] 本申请包括并设想了与本领域普通技术人员已知的特征和元件的组合。本申请已经公开的实施例、特征和元件也可以与任何常规特征或元件组合,以形成由权利要求限定的独特的发明方案。任何实施例的任何特征或元件也可以与来自其它发明方案的特征或元

件组合,以形成另一个由权利要求限定的独特的发明方案。因此,应当理解,在本申请中示出和/或讨论的任何特征可以单独地或以任何适当的组合来实现。因此,除了根据所附权利要求及其等同替换所做的限制以外,实施例不受其它限制。此外,可以在所附权利要求的保护范围内进行各种修改和改变。

[0028] 此外,在描述具有代表性的实施例时,说明书可能已经将方法和/或过程呈现为特定的步骤序列。然而,在该方法或过程不依赖于本文所述步骤的特定顺序的程度上,该方法或过程不应限于所述的特定顺序的步骤。如本领域普通技术人员将理解的,其它的步骤顺序也是可能的。因此,说明书中阐述的步骤的特定顺序不应被解释为对权利要求的限制。此外,针对该方法和/或过程的权利要求不应限于按照所写顺序执行它们的步骤,本领域技术人员可以容易地理解,这些顺序可以变化,并且仍然保持在本申请实施例的精神和范围内。

[0029] 本申请实施例提供了一种稀疏关键度预测模型训练方法,如图1所示,包括步骤S100-S600:

[0030] S100:获取训练数据集,其中,所述训练数据集包括智能系统安全关键事件发生时的环境变量 X_i 组成的正样本集P和所述智能系统安全关键事件不发生时的环境变量 X_i 组成的负样本集N;

[0031] S200:以P和N作为输入数据,进行第一阶段基于排序损失的无监督奖励模型的训练,进行数据筛选,排除N中的简单负样本,保留假性正样本;

[0032] S300:基于正样本集P构建第二阶段正样本集 P_2 ,基于所述假性正样本构建第二阶段负样本集 N_2 ,其中, $P_2 = \{(X_i, Y_i) | Y_i = 1\}$, $N_2 = \{(X_i, Y_i) | Y_i = 0\}$;

[0033] S400:以 P_2 和 N_2 作为输入数据,进行第二阶段基于改进双支网络的有监督分类模型的训练,获得第二阶段训练好的难例分类模型;

[0034] S500:获取关键数据,包括:将P中的所有 X_i 作为所述关键数据,将 N_2 中的各个 X_i 输入所述难例分类模型进行分类预测,如果将 X_i 预测为正样本,则将 X_i 作为所述关键数据;

[0035] S600:将所述关键数据作为第三阶段训练数据,对所述难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得训练好的稀疏关键度预测模型。

[0036] 本实施例中,所述关键度是指智能系统在环境 X_i 下发生安全关键事件的概率,与安全关键事件不发生的概率相比,安全关键事件发生的概率极低,导致步骤S100中获取的正样本集P中的样本数量远远小于负样本集N中的样本数量,造成训练数据集出现极端不平衡的稀疏度灾难;而且由于智能系统与环境 X_i 存在较高的时空复杂性,使得训练数据集具有高维特性,带来了维度灾难,本实施例基于训练数据集的特点,基于三阶段训练框架进行稀疏关键度预测模型的训练。

[0037] 本实施例中,通过步骤S200,旨在排除简单负样本,所述简单负样本,即在该样本环境下明显不发生安全关键事件;步骤S200降低了训练数据集的不平衡性,在排除N中的简单负样本过程中,可以设置稀疏度阈值,并实时根据公式 $IR = |N| / |P|$ 计算稀疏度,当计算得到的稀疏度小于或等于稀疏度阈值时,结束步骤S200,最终保留在N中的样本为假性正样本,将假性正样本和正样本集P共同作为难例,将难例作为构建第二阶段训练数据集的基础。

[0038] 本实施例中,步骤S300用于构建第二阶段的训练数据集,引入变量 Y_i 作为真实标签,便于第二阶段的有监督分类模型训练, $Y_i = 1$ 代表发生安全关键事件, $Y_i = 0$ 代表不发生

安全关键事件;基于步骤S300构建的第二阶段正样本集 P_2 和第二阶段负样本集 N_2 进行第二阶段的基于改进双支网络的有监督分类模型的训练,获得难例分类模型,第二阶段训练关注对难例的学习,第二阶段训练好的难例分类模型与第一阶段的无监督奖励模型相比,预测精度和模型复杂度都有提升。

[0039] 本实施例中,为了进一步提升第二阶段训练好的难例分类模型的预测准确度,通过步骤S500获取关键数据,关键数据即发生安全关键事件的环境变量 X_i ;在理想情况下,对于 P 中的所有 X_i ,难例分类模型都应该将其预测为正样本,对于 N_2 中的所有 X_i ,难例分类模型都应该将其预测为负样本;但是现实中,第二阶段训练获取的难例分类模型不一定能够对所有的训练数据都进行完美预测,通过步骤S500,将 P 中的所有 X_i 和 N_2 中由难例分类模型预测为正样本的 X_i 共同作为关键数据,基于关键数据进行第三阶段的基于密集强化学习的微调,达到提升难例分类模型预测准确度的效果。

[0040] 本实施例中,将关键度预测转化为分类问题,将稀疏关键度预测模型输出的预测为正样本的概率作为关键度预测结果。

[0041] 本实施例的稀疏关键度预测模型训练方法基于三阶段训练框架,通过第一阶段的基于排序损失的无监督奖励模型的训练,剔除了简单负样本,极大降低了训练数据集的不平衡性,第二阶段基于改进双支网络的有监督分类模型的训练关注难例的精细分类,获得难例分类模型,再通过对难例分类模型进行提高分类准确度的基于密集强化学习方法的第三阶段微调,获得稀疏关键度预测模型,训练过程能够有效解决智能系统安全关键事件的环境变量的稀疏度灾难,解决了极度不平衡数据集难以学习的问题,获得了高精度的智能系统安全关键事件概率预测模型。

[0042] 一种示例性实施例中,所述智能系统可以为智能无人系统,所述智能无人系统可以包括机器人、自动驾驶汽车、无人机、智能医疗系统、智能农业系统、智能家居系统、智能物流系统、智能火箭系统、人脸识别系统中的任何一种或多种;

[0043] 其中,所述机器人的安全关键事件可以包括跌倒、碰撞、电气危险、人生伤害中的任意一种或多种;

[0044] 所述自动驾驶汽车的安全关键事件可以包括碰撞、误解交通环境、黑客远程攻击中的任意一种或多种。

[0045] 本实施例中,对于智能无人系统的示例,以及对于安全关键事件的示例,均为示例性描述,不作为本申请的限制,本文不再赘述。

[0046] 一种示例性实施例中,步骤S200可以包括:循环执行步骤S210-S230,对所述无监督奖励模型进行第一迭代训练,直到所述训练数据集的稀疏度小于或等于稀疏度阈值,获取所有所述假性正样本:

[0047] S210:对于 P 中的每个正样本 X_i ,根据预定策略在 N 中选择对应的负样本 X_j 构建正负样本对 (x_p, x_n) ,其中, x_p 为 P 中的 X_i , x_n 为 N 中的 X_j ;

[0048] S220:依次对每一个所述正负样本对 (x_p, x_n) 分别执行以下操作:将所述正负样本对 (x_p, x_n) 作为无监督奖励模型的输入数据,并获取相应的输出标量;根据所述输出标量和奖励函数计算奖励值,比较所述奖励值和奖励阈值,当所述奖励值小于所述奖励阈值时,将所述正负样本对 (x_p, x_n) 中的 x_n 作为所述简单负样本进行排除,否则将 x_n 作为所述假性正样本保留在 N 中;

[0049] S230:计算所述训练数据集的稀疏度,判断所述稀疏度与所述稀疏度阈值的关系,当所述稀疏度大于所述稀疏度阈值时,进行下一次所述第一迭代训练。

[0050] 本实施例中,计算所述奖励值旨在对 (x_p, x_n) 进行排序,当奖励值大于或等于所述奖励阈值时,代表正负样本对 (x_p, x_n) 之间的排序距离较近;当所述奖励值小于所述奖励阈值时,代表正负样本对 (x_p, x_n) 之间的排序距离较远;将与 x_p 排序距离较远的负样本 x_n 作为简单负样本进行排除。

[0051] 本实施例中,为保证第二阶段训练的难例分类模型的召回率,所述奖励阈值的选取不能太大,需要保证保留足够多的假性正样本。

[0052] 一种示例性实施例中,可以根据公式 $IR = |N| / |P|$ 计算所述稀疏度,其中IR代表所述稀疏度, $|N|$ 为负样本集N中所述假性正样本 X_1 的数量, $|P|$ 为正样本集P中正样本 X_1 的数量。

[0053] 一种示例性实施例中,步骤S400可以包括步骤S410-S440:

[0054] S410:将 P_2 和 N_2 输入所述有监督分类模型,其中,所述有监督分类模型包括所述双支网络和第二优化器;

[0055] 循环执行步骤S420-S440,对所述有监督分类模型进行第二迭代训练,直到分类损失小于或者等于第二预设损失阈值,获取并保存第二阶段训练好的难例分类模型:

[0056] S420:基于所述双支网络,分别得到 P_2 对应的第一特征 p_a 和 N_2 对应的第二特征 p_b ,并根据所述第一特征 p_a 和所述第二特征 p_b ,得到正负类别概率向量 p ;

[0057] S430:根据分类损失函数计算所述分类损失,其中所述分类损失函数的参数包括所述正负类别概率向量 p ;

[0058] S440:判断所述分类损失与所述第二预设损失阈值的关系,当所述分类损失大于所述第二预设损失阈值时,采用第二优化器更新所述有监督分类模型的参数,包括更新所述双支网络的参数。

[0059] 本实施例中,步骤S430中,可以根据分类损失函数计算各个正负类别概率向量 p 分别对应的单一分类损失;然后根据所有的单一分类损失计算平均值,得到所述分类损失。

[0060] 一种示例性实施例中,步骤S420可以包括步骤S421-S424:

[0061] S421:根据所述双支网络中的上支,对 P_2 和 N_2 进行类平衡采样,得到上输入样本 (x_a, y_a) ,并基于各个所述上输入样本 (x_a, y_a) 进行第一骨干网络特征提取,得到第一特征 p_a ,其中,所述第一骨干网络特征提取关注正样本特征学习;

[0062] S422:根据所述双支网络中的下支,对 P_2 和 N_2 进行均匀采样,得到下输入样本 (x_b, y_b) ,并基于各个所述下输入样本 (x_b, y_b) 进行第二骨干网络特征提取,得到第二特征 p_b ,其中,所述第二骨干网络特征提取关注负样本特征学习;

[0063] S423:采用正则化后的线性分类头,将所述第一特征 p_a 和所述第二特征 p_b 进行进行拼接,得到正则化特征;

[0064] S424:采用softmax层对所述正则化特征进行概率分布计算,得到所述正负类别概率向量 p ;

[0065] 其中,所述有监督分类模型还包括所述线性分类头和所述softmax层。

[0066] 本实施例中,所述第二阶段训练好的难例分类模型包括训练好的双支网络、训练好的线性分类头和训练好的softmax层。

[0067] 本实施例中,步骤S423采用正则化后的线性分类头对所述第一特征 p_a 和所述第二特征 p_b 进行拼接,有助于防止第二阶段基于改进双支网络的有监督分类模型的训练的过拟合,而且有助于模型训练过程中选择对预测有益的特征,减少无用特征,抑制模型对噪声或无关特征的依赖性,可以帮助提高模型的鲁棒性并简化模型训练,减少模型训练过程中的震荡和梯度爆炸问题,有助于模型的高效训练,提高了模型的泛化能力,更快的得到分类效果好、泛化能力强的难例分类模型。

[0068] 一种示例性实施例中,步骤S430可以包括步骤S431:

[0069] S431:根据所述分类损失函数 $L=L_a(p, y_a)+L_b(p, y_b)$ 计算所述分类损失,其中, L_a 为焦点损失函数, L_b 为交叉熵损失函数。

[0070] 本实施例中,所述分类损失函数为焦点损失函数 L_a 和交叉熵损失函数 L_b 之和, L_a 和 L_b 分别对正负类别概率向量 p 中关注的特征并不相同,优化了分类损失函数对于第二阶段模型训练的指导效果,而且两个损失函数 L_a 和 L_b 的结合,起到了进一步正则化的作用,控制模型复杂度并防止过度拟合,减小训练过程中的局部最优解,更加适用于智能系统的关键度预测需求。

[0071] 本实施例中,所述焦点损失函数 L_a 可以减小易分类样本的权重,增加困难样本的权重,有助于获取分类精度更高的难例分类模型;所述交叉熵损失函数 L_b 可以减小训练过程中模型输出与真实标签 Y_i 之间的差距,促使模型学习到更为准确的分类边界,从而提高难例分类模型在执行分类任务时的性能。

[0072] 一种示例性实施例中,步骤S600可以包括步骤S610-S640:

[0073] S610:将所述难例分类模型转换为初始离线深度Q网络,所述初始离线深度Q网络为第三迭代训练中第一次迭代训练对应的当前离线深度Q网络;

[0074] 循环执行步骤S620-S640,对所述当前离线深度Q网络进行所述第三迭代训练,直到第三损失小于或者等于第三预设损失阈值,获取并保存训练好的稀疏关键度预测模型:

[0075] S620:将所述关键数据作为输入数据,对所述当前离线深度Q网络进行训练,并计算所述当前离线深度Q网络对应的Q值,其中,所述Q值为预测结果为正样本的概率;

[0076] S630:根据Q损失函数计算所述第三损失,其中,所述Q损失函数的参数包括所述Q值;

[0077] S640:判断所述第三损失与所述第三预设损失阈值的关系,当所述第三损失大于所述第三预设损失阈值时,采用第三优化器更新所述线性分类头和所述softmax层的参数,并相应的更新所述当前离线深度Q网络。

[0078] 本实施例中,第三阶段微调只对所述线性分类头和所述softmax层进行微调,所述线性分类头和所述softmax层是难例分类模型的最后两层。

[0079] 本实施例中,所有的关键数据组成了关键数据集D,任一个关键数据 X_i 都可以表示为 (s, a, r, s') ,其中, s 表示当前状态; a 代表当前动作; r 代表当前奖励,当关键数据 X_i 来自 P 时 $r=1$,当关键数据 X_i 来自 N_2 时 $r=0$, s' 代表下一个状态。

[0080] 本实施例中,所述Q损失函数为 $L(\theta_k) = \sum_{(s,a,r,s') \in D} (y - Q(s, a; \theta_k))^2 \mathbb{I}_{s \in S_c}$,其中, $y = r + \gamma \max_{a'} Q(s', a'; \theta_k)$, γ 代表折扣因子, θ_k 表示第 $k-1$ 次第三迭代训练时采用所述第三优化器更新的所述离线深度Q网络的参数, $\max_{a'} Q(s', a'; \theta_k)$ 代表在所述下一个状态 s' 和下

一个动作 a' 下的所述目标网络得到的最大Q值, $Q(s, a; \theta_k)$ 代表在所述当前状态 s 和所述当前动作 a 下的所述预测网络的Q值, S_c 表示所有关键数据 X_i 的当前状态 s 的集合; I 表示指示函数,是当前状态 s 的函数,当前状态 s 对应的关键数据 X_i 来自 P 时 I 取1,当前状态 s 对应的关键数据 X_i 来自 N_2 时 I 取0。

[0081] 本申请实施例还提供了一种稀疏关键度预测系统,如图2所示,包括测试数据获取模块和基于上述实施例所述的稀疏关键度预测模型训练方法获得的稀疏关键度预测模型;

[0082] 所述测试数据获取模块用于获取智能系统安全关键事件的实际环境 X ;

[0083] 所述稀疏关键度预测模型用于预测所述实际环境 X 下安全关键事件的发生概率,其中,所述发生概率为预测 X 为正样本的概率。

[0084] 本申请实施例还提供了一种稀疏关键度预测方法,如图3所示,由上述实施例所述的稀疏关键度预测系统执行,包括步骤S700-S800:

[0085] S700:基于测试数据获取模块获取智能系统安全关键事件的实际环境 X ;

[0086] S800:将 X 输入稀疏关键度预测模型,对所述实际环境 X 下安全关键事件的发生概率进行预测,其中,所述发生概率为预测 X 为正样本的概率。

[0087] 为了说明本申请实施例的技术效果,下面用一个具体示例来详细描述本申请稀疏关键度预测模型训练方法和稀疏关键度预测方法的应用效果。

[0088] 本示例的智能系统为智能火箭系统,安全关键事件为火箭接触月球表面,基于开源强化学习算法工具包Gym中的标准化环境Lunar Lander获取训练数据集,包括正样本集 P 和负样本集 N ,训练数据集中的每一个环境变量 X_i 均包括当前状态 s 和当前动作 a ,其中当前状态 s 包括火箭坐标、线速度、角速度、风力大小等状态;得到所有环境变量 X_i 后,根据公式 $IR = |N|/|P|$ 计算训练数据集的稀疏度,得到初始稀疏度为12600。

[0089] 以 P 和 N 作为输入数据,进行第一阶段基于排序损失的无监督奖励模型的训练,进行数据筛选,排除 N 中的简单负样本,保留假性正样本;本示例在训练过程中,设置奖励阈值为4.1,将奖励值小于4.1的负样本作为简单负样本进行排除,如图4所示,经过第一阶段训练,排除了负样本集 N 中的大部分简单负样本,仅保留了奖励值大于或者等于4.1的假性正样本和 P 中的正样本,重新计算训练数据集的稀疏度,得到的稀疏度为3,大大降低了训练数据集的稀疏度。

[0090] 基于正样本集 P 构建第二阶段正样本集 P_2 ,基于所述假性正样本构建第二阶段负样本集 N_2 ,其中, $P_2 = \{(X_i, Y_i) | Y_i = 1\}$, $N_2 = \{(X_i, Y_i) | Y_i = 0\}$ 。

[0091] 测试一:将 P_2 和 N_2 中的 X_i ,分别输入第二阶段训练好的难例分类模型stage1+2和经过三阶段训练的稀疏关键度预测模型stage1+2+3,进行关键度预测,关键度预测结果准确率见表1,通过表1可知,经过三阶段训练的稀疏关键度预测模型的预测结果与所述难例分类模型相比,准确率进一步提高,说明基于密集强化学习方法的第三阶段微调是有效的,进一步提升了难例分类模型分类准确度。

[0092] 表1关键度预测结果准确率

[0093]

输入数据	难例分类模型stage1+2	稀疏关键度预测模型stage1+2+3
P_2 中的 X_i	99.13%	99.27%
N_2 中的 X_i	98.41%	99.06%

[0094] 测试二:将 P_2 和 N_2 中的 X_i ,分别输入本申请中的第二阶段训练好的难例分类模型

stage1+2和经过三阶段训练的稀疏关键度预测模型stage1+2+3,同时将 P_2 和 N_2 中的 X_i 分别输入三个传统模型,包括B原始双支网络模型(简称BBN,全称Bilateral-Branch Network)、类别平衡得分模型(简称CBS,全称Class Balance Score Model)、解偶训练模型(简称DT,全称Decoupled Training Model)进行关键度预测,预测结果对比图如图5和图6所示。

[0095] 图5为ROC曲线(全称Receiver Operating Characteristic Curve)对比图,其横坐标为假阳性率(简称FPR,全称False Positive Rate),其纵坐标为真阳性率(简称TPR,全称True Positive Rate),ROC曲线上的点基于不同的二分类阈值得到,根据各条ROC曲线分别计算其下的面积,得到对应的AUC(全称Area Under the Curve),AUC越接近1,代表模型的分性能更好,其中,稀疏关键度预测模型stage1+2+3的ROC曲线对应的AUC为0.9853,难例分类模型stage1+2的ROC曲线对应的AUC为0.9612,BBN的ROC曲线对应的AUC为0.8325,CBS的ROC曲线对应的AUC为0.7267,DT的ROC曲线对应的AUC为0.7412。

[0096] 图6为PR曲线(全称Precision-Recall Curve)对比图,其横坐标为召回率Recall,纵坐标为精准率Precision,PR曲线上的点基于不同的二分类阈值得到,其中稀疏关键度预测模型stage1+2+3在不同的二分类阈值下的精准率和召回率均高于三个传统模型BBN、CBS和DT。

[0097] 综上,采用本申请实施例获得的难例分类模型stage1+2和稀疏关键度预测模型stage1+2+3与其他三个传统模型相比,具有更高的召回率和精确率,并且stage1+2+3的分性能比stage1+2要更为优越。

[0098] 本领域普通技术人员可以理解,上文中所公开方法中的全部或某些步骤、系统、装置中的功能模块/单元可以被实施为软件、固件、硬件及其适当的组合。在硬件实施方式中,在以上描述中提及的功能模块/单元之间的划分不一定对应于物理组件的划分;例如,一个物理组件可以具有多个功能,或者一个功能或步骤可以由若干物理组件合作执行。某些组件或所有组件可以被实施为由处理器,如数字信号处理器或微处理器执行的软件,或者被实施为硬件,或者被实施为集成电路,如专用集成电路。这样的软件可以分布在计算机可读介质上,计算机可读介质可以包括计算机存储介质(或非暂时性介质)和通信介质(或暂时性介质)。如本领域普通技术人员公知的,术语计算机存储介质包括在用于存储信息(诸如计算机可读指令、数据结构、程序模块或其他数据)的任何方法或技术中实施的易失性和非易失性、可移除和不可移除介质。计算机存储介质包括但不限于RAM、ROM、EEPROM、闪存或其他存储器技术、CD-ROM、数字多功能盘(DVD)或其他光盘存储、磁盒、磁带、磁盘存储或其他磁存储装置、或者可以用于存储期望的信息并且可以被计算机访问的任何其他的介质。此外,本领域普通技术人员公知的是,通信介质通常包含计算机可读指令、数据结构、程序模块或者诸如载波或其他传输机制之类的调制数据信号中的其他数据,并且可包括任何信息递送介质。

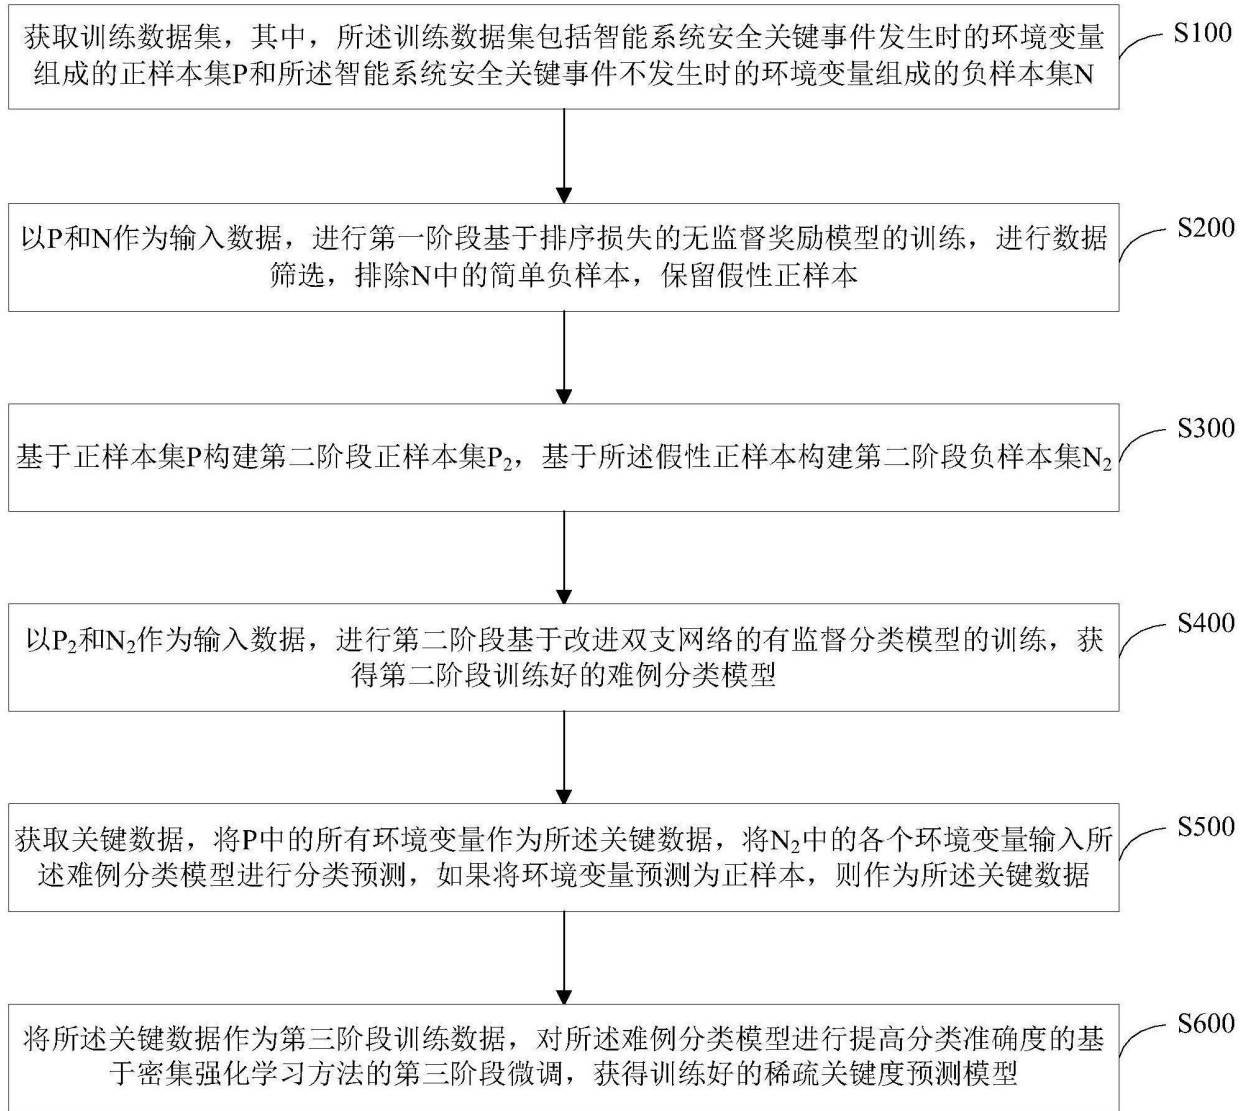


图1

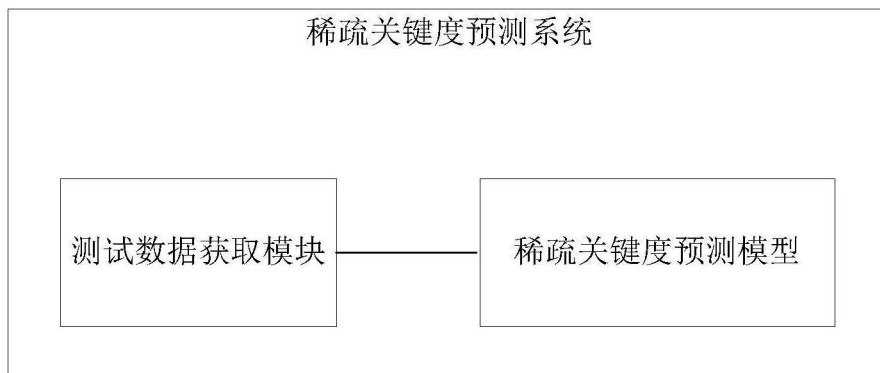


图2

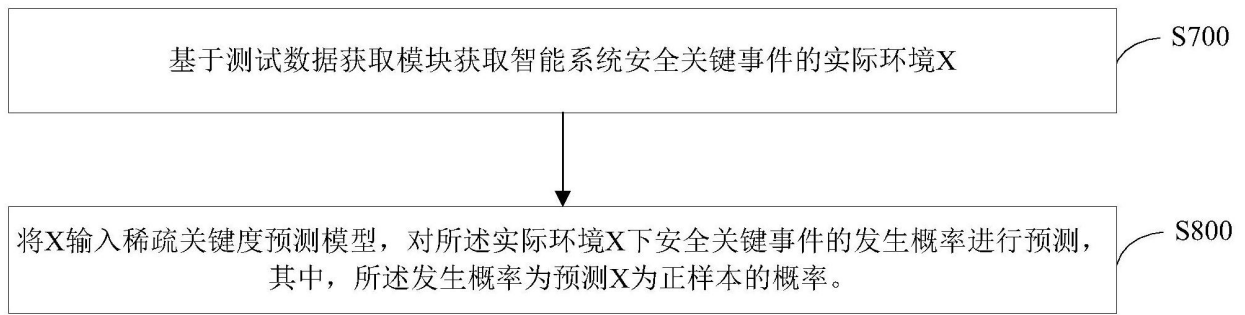


图3




图4




图5




图6